

# 基于双注意力机制优化 CNN 架构的 GIS 局部放电模式识别

王彦彪<sup>1</sup>, 陈振勇<sup>1</sup>, 郭文萍<sup>1</sup>, 王宗宝<sup>1</sup>, 黄银汉<sup>2</sup>

(1. 国网甘肃省电力公司白银供电公司, 甘肃 白银 730900; 2. 国电南瑞南京控制系统有限公司, 江苏 南京 211100)

**摘要:**GIS 局部放电模式识别是其绝缘状态评估的重要部分, 为对 GIS 局部放电信号进行准确、高效识别, 提出一种基于双注意力机制优化 CNN 的 GIS 局部放电信号模式识别方法。首先, 搭建 GIS 局部放电测试平台, 并在 GIS 气室内人为设置 4 种典型缺陷, 分别通过超高频和超声波检测法对不同缺陷局部放电信号进行采集; 然后, 基于二者数据特点分别进行数据预处理, 并构建由超高频局部放电谱图图像特征和超声信号格拉米角场密度分布组成的特征空间; 最后, 通过双注意力机制优化的卷积神经网络对输入图像进行深层特征提取, 由网络尾端的 Softmax 分类器进行结果预测。结果表明: 融合多特征参数算法能够达到 97.57% 左右的识别准确率, 高于单一特征识别率; 同时在同一网络输入时, 双注意力机制优化的卷积神经网络在算法识别率、训练速度和鲁棒性等方面均优于常见网络算法。

**关键词:**局部放电; 气体绝缘电器; 卷积神经网络; 模式识别

DOI:10.19781/j.issn.1673-9140.2022.02.003 中图分类号: TM85 文章编号: 1673-9140(2022)02-0022-08

## PD pattern recognition for GIS based on CNN architecture optimized by the double attention mechanism

WANG Yanbiao<sup>1</sup>, CHEN Zhenyong<sup>1</sup>, GUO Wenping<sup>1</sup>, WANG Zongbao<sup>1</sup>, HUANG Yinhan<sup>2</sup>

(1. Baiyin Power Supply Company, State Grid Gansu Electric Power Company, Baiyin 730900, China;

2. NARI Technology Nanjing Control Systems Co., Ltd., Nanjing 211100, China)

**Abstract:** The PD pattern recognition is an important part of the insulation state evaluation of GIS. For the purpose of the accurate and efficient identification of PD signals, a new method of PD signal pattern recognition is proposed based on CNN optimized by the dual attention mechanism in this paper. Firstly, the GIS PD test platform is built, and four typical defects are set up in GIS chamber. The PD signals of different defects are collected by the UHF and ultrasonic detection respectively. Then, the data preprocessing is carried out based on the characteristics of the data obtained by methods mentioned above respectively. The feature space composed by the image features of UHF PD spectrum and the gram angle field density distribution of ultrasonic signal are constructed. Finally, the input image is extracted through the method of convolutional neural network optimized by double attention mechanism, and the results are predicted by a softmax classifier at the end of the network. It is shown that 97.57% recognition accuracy can be achieved by the fusion algorithm, which is higher than the recognition rate considering the single feature. The convolutional neural network optimized by the double attention mechanism is superior to the common algorithm in the aspects

收稿日期: 2021-03-19; 修回日期: 2021-06-18

基金项目: 国家电网公司科技项目 (SGTJBHO0YJJS1902138)

通信作者: 王彦彪 (1989-), 男, 硕士, 工程师, 主要从事电网智能运检技术研究; E-mail: 2643469402@qq.com

of the recognition rate, training speed and robustness.

**Key words:** partial discharge; gas insulated switchgear; convolution neural network; pattern recognition

局部放电(partial discharge, PD)是反映气体绝缘开关设备(gas insulated switchgear, GIS)内部绝缘状况的重要指标之一<sup>[1-2]</sup>。由于不同缺陷引发的局部放电现象和机理不同,其对内部绝缘造成的劣化程度各异,因此,有必要对 GIS 内部出现的局部放电信号进行识别,以保证 GIS 的安全稳定运行。

局部放电信号识别可以分为特征提取和分类器识别两步,其中信号的特征提取是识别成功与否的关键。针对局部放电信号的特征提取,常采用统计参数法<sup>[3-4]</sup>、分形特征<sup>[5]</sup>、图像矩特征<sup>[6]</sup>、纹理特征<sup>[7]</sup>等,但是通过这些方法提取得到的特征数量较多,造成特征空间维度较高,不仅有严重的特征冗余,还给分类器带来负担。同时,上述的特征提取方法需要大量的专家经验和先验知识,在缺乏理论背景的前提下,较难提取出合适的特征。

目前,随着深度学习在图像识别、语音识别、语义分析等领域的成功应用,基于深度学习实现端到端的故障智能化诊断逐渐成为研究热点。如:文献[8]采用卷积神经网络对直流交联聚乙烯电缆的局部放电类型进行识别;文献[9]通过卷积神经网络对 5 种局放缺陷类型的时域波形图像进行识别;文献[10]基于卷积神经网络对高压电缆局部放电模式进行识别。可见,卷积神经网络(convolutional neural network, CNN)架构作为目前应用最为广泛且成熟的深度学习架构已被应用在各类电气设备的故障诊断中。然而传统 CNN 架构存在问题<sup>[11-12]</sup>:①网络卷积、池化时没有考虑各层结构中不同特征重要性,徒增网络计算量,影响网络性能;②网络池化往往采用平均池化或最大池化,针对不同深度特征缺乏池化方式的科学合理选择。

针对上述问题,在 CNN 架构的基础上,本文提出双注意力模块优化的 CNN 架构,即在传统卷积、池化过程中加入包含通道和空间注意力机制的模块,以解决不同通道特征和相同通道不同位置特征的重要性选择、加权问题。据此,提出一种基于双注意力机制优化的 GIS 局部放电信号识别方法,通过

超高频和超声波检测法对不同缺陷局部放电信号进行采集,构建由超高频局部放电谱图图像特征和超声信号格拉米角场密度分布组成的特征空间,基于所提方法完成数据深层特征提取和类型识别。

## 1 局部放电实验

### 1.1 样本制作

基于 GIS 制造过程中可能因人为失误而造成的 4 种常见缺陷建立实验模型<sup>[13-14]</sup>,如图 1 所示。




图 1 典型缺陷试样

Figure 1 Typical defect sample

1)表面污秽。在二次侧瓷套内导体表面含油脂。

2)金属微粒。GIS 罐中含金属微粒,微粒尺寸约为  $5\text{ mm} \times 3\text{ mm} \times 1\text{ mm}$ 。

3)电晕放电。通过在操作手柄连接杆上焊接突起实现,突起尺寸约为  $5\text{ mm} \times 5\text{ mm} \times 2\text{ mm}$ 。

4)沿面放电。通过内部金属环的磨损缺陷模拟,缺损深度为  $2\text{ mm}$ ,长度为  $10\text{ mm}$ 。

### 1.2 局部放电测试平台及加压方式

局部放电测试平台如图 2 所示,变压器为无晕试验变压器(YDTW-25/100),保护电阻为  $10\text{ kW}$  保护性水阻。采用 Tektronix DPO7104 高速数字存储示波器记录 PD 波形,超高频探头的检测频段为  $300 \sim 1\,500\text{ MHz}$ ,超声波传感器检测中心频率为  $40\text{ kHz}$ 。实验在高压屏蔽大厅进行,针对无缺陷 GIS 的加压测试背景噪声控制在  $3\text{ pC}$  左右。

根据高压开关设备试验标准 IEC 62271-203,测试设备必须在耐受电压下承受  $1\text{ min}$  的最大应力,在此期间发生的局部放电信号应被忽略, $1\text{ min}$  后外施电压降至 PD 测试电压。GIS 额定电压  $U_r$  为

15 kV,在 45 kV 耐受电压下施加 1 min 的升压,然后将电压降至  $1.2U_r/1.73=10.4$  kV 以测量局部放电。每次测量完成后将实验设备闲置 1 h,然后再测量下一组数据。GIS 局部放电过程中的电压施加曲线如图 3 所示。




图 2 局部放电测试平台

Figure 2 Partial discharge test platform




图 3 外施电压

Figure 3 Applied voltage

### 1.3 局部放电信号

4 种典型缺陷样本的超高频信号 PRPD 谱图如图 4 所示,可见不同缺陷下测得的 PRPD 谱图形态各异,可将其作为分类算法输入进行识别,为后续算法识别便捷,将数据进行归一化处理,使信号幅值分布在  $[0,1]$  范围内。采用统计、图像特征等对局部放电 PRPD 谱图进行特征提取,这些方法均需要较为丰富的专业背景,难以满足电力设备智能诊断的需求<sup>[15]</sup>。对采集的 PRPD 谱图进行预处理后,本文采用后续深度学习算法对其进行深度特征提取,免去人工特征提取步骤,简化诊断流程。

归一化处理后的 4 种典型缺陷样本超声波信号如图 5 所示,采样频率为 40 kHz,采集时间为 30 ms。由于采样点为与时间相关的一维序列,且长度为  $10^4$  样本点,若将其直接作为网络的输入,不仅会导致网络运行缓慢,还存在数据点丢失的情况。据此,本文将测得的时序信号采用格拉米角场(gramian angular field, GAF)密度表示<sup>[16-17]</sup>,如图 6 所示,将数据映射到极坐标系中,而不是笛卡尔坐标系。




图 4 超高频局放信号 PRPD 谱图

Figure 4 PRPD patterns of UHF PD signal




图 5 超声波局放信号

Figure 5 Ultrasonic PD signal




图 6 超声波局放信号的 GAF 密度分布

Figure 6 GAF density distribution of ultrasonic PD signal

GAF 图像有 2 个优点:①极坐标系保持笛卡尔坐标系不存在的绝对时间关系;②该方程能够产生唯一的映射。因此当数据反演时,GAF 图像产生的变换是无损的<sup>[18]</sup>,其主要显示数据点之间的时间相关性,同时保留了空间位置信息。

基于局部放电实验平台,针对每类缺陷,本文通过超高频检测法采集局部放电 PRPD 谱图 200 张,通过超声波检测法采集局部放电信号 150 条。

## 2 双注意力机制优化的 CNN 架构

### 2.1 通道注意力模块

通道注意力模块(channel attention module, CAM)通过加权不同通道间的相关性生成特征图,由于每个通道都可被看作一个特征检测器,该机制可以使模型更加关注有效信息的通道特征<sup>[19]</sup>。由于卷积运算只能在局部空间中进行,CAM 很难获得足够的信息来提取不同通道间的关系,因此,将通道上的整个空间特征编码为全局特征,使用全局平均池化和全局最大池化来实现。整体思路<sup>[20]</sup>:将输入特征分别经过全局平均池化和全局最大池化后获得全局描述特征;再由 2 层结构的感知器进行特征连接,将由多层感知器输出的特征进行元素加权、融合;最后,将  $M_c$  特征和输入特征  $F$  进行元素相乘得到最终的特征,整体提取过程如图 7 所示。




图 7 通道注意力模块

Figure 7 Channel attention module

平均池化和最大池化的过程分别如下:

$$F_{\text{avg}} = \frac{1}{H \cdot W} \sum_{i=1}^H \sum_{j=1}^W F(i, j) \quad (1)$$

$$F_{\text{max}} = \max(F(i, j)) \quad (2)$$

式(1)、(2)中  $F_{\text{avg}}$ 、 $F_{\text{max}}$  分别为具有输入特征映射  $F$  的全局平均和全局最大池化结果; $H$ 、 $W$  分别为输入特征的高、宽。

通道注意力  $M_c$  的计算公式为

$$M_c(F) =$$

$$\sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (3)$$

其中, $W_0$ 、 $W_1$  为多层感知器中的全连接结构, $W_0$  层起降维作用, $W_1$  层将输入特征恢复至原始尺度。为了降低模型的复杂度,采用含 2 个全连接层的瓶颈式结构  $\sigma$  表示 Sigmoid 操作。

### 2.2 空间注意力模块

与通道注意力机制不同的是,空间注意力机制更加关注目标特征位置,利用特征的空间关系生成空间注意力图<sup>[21]</sup>,空间注意力模块(spatial attention module, SAM)整体流程如图 8 所示。计算整体思路<sup>[22]</sup>:首先,对输入特征  $F$  的通道进行轴向全局平均池化和全局最大池化;然后,将池化结果连接生成一个有效的特征描述符;最后,经过卷积降维生成空间注意力图  $M_s(F)$ 。计算过程为

$$M_s(F) = \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (4)$$

其中  $\sigma$  为 Sigmoid 操作,  $7 \times 7$  为卷积核大小。通过空间注意力图可反映输入特征需关注或抑制的位置。




图 8 空间注意力模块

Figure 8 Spatial attention module

### 2.3 整体网络架构

为了提高局部放电识别模型的性能,在特征提取网络中加入 CAM、SAM。通道注意力模块分别采用平均池化和最大池化压缩特征映射的空间维数,空间注意力模块分别沿信道维度应用平均、最大池化。

注意力模块是一个轻量级的通用模块,可以集成到 CNN 中进行端到端的训练。在 5 层 CNN 架构的基础上,本文引入双注意力模块进行优化,整体结构如图 9 所示,图 9(a)为单个 CSAM 结构,对于每个卷积块的特征图 A,添加 2 个连续的注意力模块(CAM、SAM),并将处理后的特征 B 传递给下一个卷积模块;图 9(b)为含双注意力模块的 CNN 架构,输入为局部放电 PRPD 谱图和 GAF 图像,通过 5 层 CSAM 结构进行深层特征提取,再经 Flatten 层将多维输入一维化,最后由 2 层全连接层输出至 Softmax 分类识别。




图9 整体网络架构

Figure 9 Overall network architecture

所提网络架构的结构参数如表1所示,网络输入尺寸设定为 $256 \times 256 \times 1$ ;M1~M5为CSAM结构,分别含2个 $3 \times 3 \times 32$ 、 $3 \times 3 \times 32$ 、 $3 \times 3 \times 64$ 、 $3 \times 3 \times 64$ 、 $3 \times 3 \times 128$ 的优化卷积块。在Flatten层将特征图矢量化为 $1 \times 1 \times 8192$ ,实现从卷积层到全连接层的过渡;然后,将8192个元素分别输出至含150、4个神经元的双层全连接层;最后,将全连接特征输出至Softmax进行局部放电类型识别。

表1 网络参数

Table 1 Network parameters

网络层名	核参数	输出尺度
Input	—	$256 \times 256 \times 1$
M1	$(3 \times 3 \times 32) \times 2$	$128 \times 128 \times 32$
M2	$(3 \times 3 \times 32) \times 2$	$64 \times 64 \times 32$
M3	$(3 \times 3 \times 64) \times 2$	$32 \times 32 \times 64$
M4	$(3 \times 3 \times 64) \times 2$	$16 \times 16 \times 64$
M5	$(3 \times 3 \times 128) \times 2$	$8 \times 8 \times 128$
Flatten	—	$1 \times 1 \times 8192$
FC1	$150 \times 8192, 150 \times 1$	$1 \times 1 \times 150$
FC2	$4 \times 150, 4 \times 1$	$1 \times 1 \times 4$
Softmax	—	$1 \times 1 \times 4$

### 3 结果分析

通过十折交叉验证对GIS局部放电类型<sup>[23-24]</sup>进行识别,即将局部放电数据集分成10份,依次将其中9份做训练,其余1份做验证,10次结果的均值作为对算法精度的估计。本文分别对网络训练损失函数值、识别准确率及 $F_1$ 指数进行分析,探讨不

同特征输入时的网络性能以及不同网络在相同特征输入时的性能。

#### 3.1 网络输入对比分析

针对不同特征输入时的网络性能,本文对4种情形进行讨论:

情形1 网络输入为局部放电PRPD谱图时采用CSAM-CNN识别模型;

情形2 网络输入为局部放电时序信号时采用CSAM-CNN识别模型;

情形3 网络输入为局部放电格拉米角场密度分布时采用CSAM-CNN识别模型;

情形4 网络输入为局部放电PRPD谱图及格拉米角场密度分布时采用CSAM-CNN识别模型。

不同网络输入时的损失函数值如图10所示,在网络收敛速度方面,情形4在40步左右逐步收敛,情形1/2/3在迭代前期有较小的振荡,80步左右趋于收敛;在网络收敛方面,loss稳定值大小依次为情形 $4 < 1 < 3 < 2$ 。综上,网络输入为局部放电PRPD谱图及格拉米角场密度分布时的网络收敛较快,且保持较低的网络损失值。




图10 网络输入对loss值影响分析

Figure 10 Influence analysis of network input on loss value

基于十折交叉验证的识别准确率如表2所示,识别准确率反映了训练完成网络对测试集数据的识别程度。从表2可以看出,与其他情形比较,情形4的平均准确率最高,为97.57%,而情形2的平均准确率最低,为66.79%。说明采用超声波局部放电时序信号作为网络输入不仅使网络迭代速度降低,还降低了识别准确率。而融合超高频局放PRPD谱图和超声波局放格拉米角场密度分布的数据特征具有更好的故障表征能力,能够较为全面的反映局放类型。

表 2 识别准确率

Table 2 Recognition accuracy %

次数	各情形识别准确率			
	1	2	3	4
1	87.14	68.57	92.14	98.57
2	85.00	65.00	86.43	99.29
3	86.43	71.43	85.71	96.43
4	85.71	66.43	90.71	97.14
5	88.57	67.86	92.14	99.29
6	85.00	70.71	90.00	97.14
7	89.29	64.29	91.43	96.43
8	90.71	65.00	91.43	96.43
9	90.00	64.29	88.57	97.14
10	87.86	64.29	88.57	97.86
平均准确率/%	87.57	66.79	89.71	97.57

基于十折交叉验证的  $F_1$  指数结果如表 3 所示,  $F_1$  指数的计算公式为

$$F_1 = \frac{2T_P}{2T_P + F_P + F_N} \quad (5)$$

其中,  $T_P$  表示预测为真, 实际也为真;  $F_P$  表示预测为真, 实际为假;  $F_N$  表示预测为假, 实际为真。  $F_1$  指数通过实现精确率和召回率间的平衡, 从而能够更加客观的描述网络预测性能, 其值越接近 1 说明性能越好。从表 3 可以看出, 情形 4 的  $F_1$  指数最接近 1, 且均高于其他情形, 说明情形 4 的网络综合性能最佳。

表 3  $F_1$  指数

Table 3  $F_1$  index

次数	各情形 $F_1$ 指数			
	1	2	3	4
1	0.951	0.904	0.959	0.994
2	0.955	0.929	0.953	0.989
3	0.955	0.921	0.955	0.998
4	0.959	0.905	0.954	0.988
5	0.953	0.916	0.956	0.985
6	0.954	0.929	0.956	0.993
7	0.955	0.901	0.951	0.996
8	0.954	0.928	0.950	0.989
9	0.957	0.921	0.958	0.987
10	0.958	0.902	0.959	0.980

### 3.2 不同深度学习算法对比分析

针对不同网络在相同特征输入时的性能, 本文对 2 种情形进行讨论:

情形 5 网络输入为局部放电 PRPD 谱图及格拉米角场密度分布时采用栈式自编码器 (stacked auto encoder, SAE) 识别模型;

情形 6 网络输入为局部放电 PRPD 谱图及格拉米角场密度分布时采用卷积神经网络识别模型。

采用不同深度学习网络时的损失函数值如图 11 所示, 在网络收敛速度方面, 3 个网络均在 40 步左右趋于稳定, 有较快的收敛速度; 在网络收敛方面, loss 稳定值大小依次为情形  $4 < 6 < 5$ 。综上, 采用 CSAM-CNN 识别模型能够保持较低的网络损失值。




图 11 网络类型对 loss 值影响分析

Figure 11 Influence analysis of network type on loss value

识别准确率、 $F_1$  指数分别如表 4、5 所示, 可以看出, 在同一特征输入下, 采用 CSAM-CNN 识别模型不仅在识别准确率上高于其他模型, 而且在  $F_1$  指数上也更接近 1。说明与其他常用深度学习相比, CSAM-CNN 具有更快收敛速度、更低损失函数值, 同时故障识别率更高、网络综合性能更佳。

表 4 识别准确率

Table 4 Recognition accuracy %

次数	各情形识别准确率		
	4	5	6
1	98.57	93.80	92.80
2	99.29	95.12	93.23
3	96.43	95.17	93.04
4	97.14	95.34	92.75
5	99.29	94.67	92.60
6	97.14	94.20	92.60
7	96.43	93.80	93.16
8	96.43	95.40	92.70
9	97.14	94.49	92.98
10	97.86	94.21	92.77
平均准确率/%	97.57	94.67	92.88

表 5  $F_1$  指数  
Table 5  $F_1$  index

次数	各情形 $F_1$ 指数		
	4	5	6
1	0.994	0.970	0.956
2	0.989	0.974	0.950
3	0.998	0.962	0.955
4	0.988	0.967	0.957
5	0.985	0.972	0.950
6	0.993	0.966	0.950
7	0.996	0.964	0.952
8	0.989	0.979	0.953
9	0.987	0.967	0.958
10	0.980	0.976	0.959
平均 $F_1$ 指数	0.990	0.967	0.955

## 4 结语

针对 GIS 局部放电信号进行准确、高效识别,提出了一种基于双注意力机制优化 CNN 的 GIS 局部放电信号模式识别方法,得出结论:

1) 当采用融合局部放电 PRPD 谱图和格拉米角场密度分布图作为 CSAM-CNN 识别模型输入时,能够达到 97.57% 左右的识别准确率,高于采用单一特征时的模型识别率;

2) 在同一特征输入时,采用 CSAM-CNN 识别模型具有更快收敛速度、更低损失函数值,同时故障识别率也更高、网络综合性能更佳。

## 参考文献:

- [1] 张利,屈斌,王永宁,等. GIS 壳体振动机理和局部放电优化诊断与应用[J]. 中国电力,2022,55(3):80-86.  
ZHANG Li, QU Bin, WANG Yongning, et al. GIS shell vibration mechanism and partial discharge optimization diagnosis[J]. Electric Power, 2022, 55(3): 80-86.
- [2] 朱航,高波,刘亚婕,等. 硫腐蚀对变压器油纸绝缘局部放电过程影响研究[J]. 高压电器,2020,56(7):181-188.  
ZHU Hang, GAO Bo, LIU Yajie, et al. Influence of sulfur corrosion on partial discharge process of transformer oil-paper insulation[J]. High Voltage Apparatus, 2020, 56(7): 181-188.
- [3] 吴童,孙抗,师文文. 基于 AVMD-自适应小波包法的电

缆局部放电去噪研究[J]. 电力系统保护与控制,2020,48(14):95-103.

WU Tong, SUN Kang, SHI Wenwen. Research on cable partial discharge denoising based on an AVMD-adaptive wavelet packet method[J]. Power System Protection and Control, 2020, 48(14): 95-103.

- [4] 牛勃,魏莹,马飞越,等. 电气设备长间歇性局部放电检测系统研究[J]. 电测与仪表,2021,58(7):173-179.

NIU Bo, WEI Ying, MA Feiyue, et al. Research on long-interval sparse partial discharge detection system for electrical equipment[J]. Electrical Measurement & Instrumentation, 2021, 58(7): 173-179.

- [5] 于瑞,高波,周芄,等. 不同曲率下针—板沿面放电模型白斑发展过程及放电特性[J]. 高电压技术,2020,46(4):1387-1395.

YU Rui, GAO Bo, ZHOU Peng, et al. Development process and discharge characteristics of white marks on the pressboard surface in needle-plane model under different curvatures[J]. High Voltage Engineering, 2020, 46(4): 1387-1395.

- [6] REFFAS A, BEROUAL A, MOULAI H. Comparison of creeping discharges propagating over pressboard immersed in olive oil, mineral oil and other natural and synthetic ester liquids under DC voltage[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2019, 26(6): 2019-2026.

- [7] 李斯盟,李清泉,刘洪顺,等. 基于雷达谱图的交直流复合电压下油纸针板模型局放阶段识别[J]. 中国电机工程学报,2018,38(19):5897-5908+5948.

LI Simeng, LI Qingquan, LIU Hongshun, et al. A recognition method for PD development stage in oil-pressboard insulation with needle-plate model at AC-DC mixed voltage based on radar maps[J]. Proceedings of the CSEE, 2018, 38(19): 5897-5908+5948.

- [8] 杨可军,杨建旭,陈思宝,等. 基于深度可分离卷积及 SVD 输电线路缺陷检测[J]. 智慧电力,2020,48(10):64-69+77.

YANG Kejun, YANG Jianxu, CHENG Sibao, et al. Methods of defect detection in transmission line based on depthwise separable convolution and SVD[J]. Smart Power, 2020, 48(10): 64-69+77.

- [9] 朱煜峰,许永鹏,陈孝信,等. 基于卷积神经网络的直流 XLPE 电缆局部放电模式识别技术[J]. 电工技术学报,2020,35(3):659-668.

- ZHU Yufeng, XU Yongpeng, CHEN Xiaoxin, et al. Partial discharge pattern recognition technology of DC XLPE cable based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(3):659-668.
- [10] 万晓琪, 宋辉, 罗林根, 等. 卷积神经网络在局部放电图像模式识别中的应用[J]. 电网技术, 2019, 43(6): 2219-2226.
- WAN Xiaoqi, SONG Hui, LUO Lingen, et al. Application of convolutional neural network in pattern recognition of partial discharge image[J]. Power System Technology, 2019, 43(6): 2219-2226.
- [11] REN M, ZHANG C X, DONG M, et al. Fault prediction of gas-insulated system with hypersensitive optical monitoring and spectral information[J]. International Journal of Electrical Power & Energy Systems, 2020, 119:105945.
- [12] 魏文兵, 毛钧毅, 荣娜, 等. 采用随机矩阵与 CNN 的暂态电压稳定快速评估[J]. 电网与清洁能源, 2020, 36(11):68-76.
- WEI Wenbing, MAO Junyi, RONG Na, et al. Fast evaluation of transient voltage stability using random matrix and convolutional neural network[J]. Power System and Clean Energy, 2020, 36(11):68-76.
- [13] 严智民, 杨凯, 王诗航, 等. 硅脂对硅橡胶电树枝劣化特性的影响机制研究[J]. 中国电机工程学报, 2019, 39(2):604-611.
- YAN Zhimin, YANG Kai, WANG Shihang. Study on the mechanism of silicone grease on electrical tree degradation of silicone rubber[J]. Proceedings of the CSEE, 2019, 39(2):604-611.
- [14] 杨帆, 王干军, 彭小圣, 等. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备, 2018, 38(5):123-128.
- YANG Fan, WANG Ganjun, PENG Xiaosheng, et al. Partial discharge pattern recognition of high voltage cable based on convolutional neural network[J]. Electric Power Automation Equipment, 2018, 38(5):123-128.
- [15] LYU C G, HUO Z Q, CHENG X, et al. Distributed optical fiber sensing intrusion pattern recognition based on GAF and CNN[J]. Journal of Lightwave Technology, 2020, 38(15):4174-4182.
- [16] ZHANG G, SI Y J, WANG D, et al. Automated detection of myocardial infarction using a gramian angular field and principal component analysis network[J]. IEEE Access, 2019, 7:171570-171583.
- [17] TANG H H, LIAO Z Q, CHEN P, et al. A novel convolutional neural network for low-speed structural fault diagnosis under different operating condition and its understanding via visualization[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 9167272.
- [18] MA J Y, ZHANG H, YI P, et al. SCSCN: a separated channel-spatial convolution net with attention for single-view reconstruction[J]. IEEE Transactions on Industrial Electronics, 2020, 67(10):8649-8658.
- [19] ZHANG L, CHEN C S, MOW W H. Accurate modeling and efficient estimation of the print-capture channel with application in barcoding[J]. IEEE Transactions on Image Processing, 2019, 28(1):464-478.
- [20] 张开放, 张黎, 赵彤. 高频正弦电应力对气-固绝缘局部放电的影响[J]. 高电压技术, 2019, 45(12):3879-3888.
- ZHANG Kaifang, ZHANG Li, ZHAO Tong. Influence of high frequency sinusoidal electrical stress on partial discharge of gas-solid insulation[J]. High Voltage Engineering, 2019, 45(12):3879-3888.
- [21] ZHU M H, JIAO L C, LIU F, et al. Residual spectral-spatial attention network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1):449-462.
- [22] 汤浩, 李金忠, 张贺军, 等. 特高压直流换流变压器阀侧套管高环温强电流下轴径向的温度分布规律[J]. 中国电机工程学报, 2017, 37(18):5494-5503.
- TANG Hao, LI Jinzhong, ZHANG Hejun, et al. Analysis of temperature distribution in the radial direction of the valve under casing hightemperature and high current in the UHVDC converter transformer[J]. Proceedings of the CSEE, 2017, 37(18):5494-5503.
- [23] LIU Q L, CHE X J, BIE M. R-STAN: residual spatial-temporal attention network for action recognition[J]. IEEE Access, 2019, 7:82246-82255.
- [24] 薛磊, 柴琦, 兀鹏越, 等. 一种高分辨率的便携式 GIS 局部放电检测装置[J]. 电力科学与技术学报, 2019, 34(1):149-153.
- XUE Lei, CHAI Qi, WU Pengyue, et al. A high resolution portable partial discharge detection device for GIS[J]. Journal of Electric Power Science and Technology, 2019, 34(1):149-153.